

O MICROPROCESSADOR GENÉRICO

Professor: Alan Sovano, M.Sc.

Disciplina: Microprocessadores (2024.4)



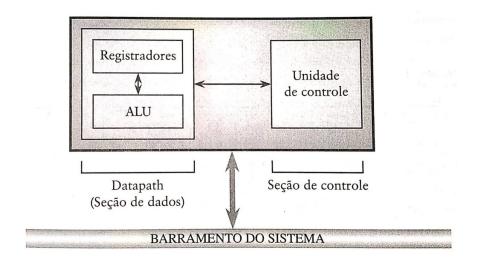


TÓPICOS

- Estrutura simplificada de um microprocessador
- O ciclo de instrução de um microprocessador
- Microarquitetura interna de um microprocessador genérico
- Tipos de dados
- Pipelining
- Processadores com múltiplos cores e múltiplos threads

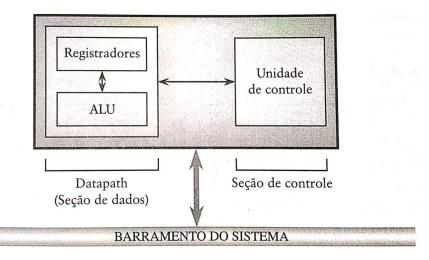


• Um **microprocessador**, ou simplesmente **processador**, pode ser descrito, de forma simplificada, a partir da figura abaixo:



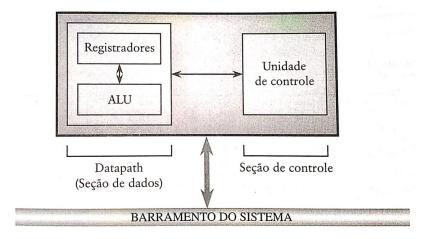


Esse sistema possui duas áreas distintas: a primeira é a área de processamento de dados, a qual é composta por um conjunto de registradores e uma unidade lógica e aritmética (ou ULA/UAL/ALU). Ela realiza todas as operações lógicas e aritméticas.





• A segunda área é a da **unidade de controle** (UC), responsável por: sincronizar todo o sistema computacional; enviar comandos para memória e/ou dispositivos de E/S; decodificar instruções que serão interpretadas por microcódigo ou executadas diretamente via hardware.

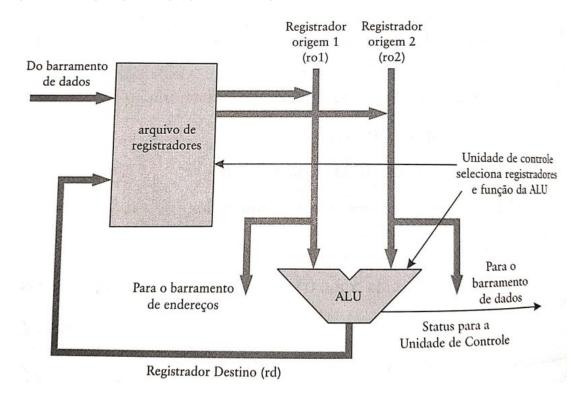




- A figura ao lado ilustra o caminho dos dados ou o datapath de uma UCP (Parte da UCP composta pela ULA junto com suas entradas e saídas);
- O conjunto de registradores da UCP pode ser chamado de arquivo de registradores ou de register-file.

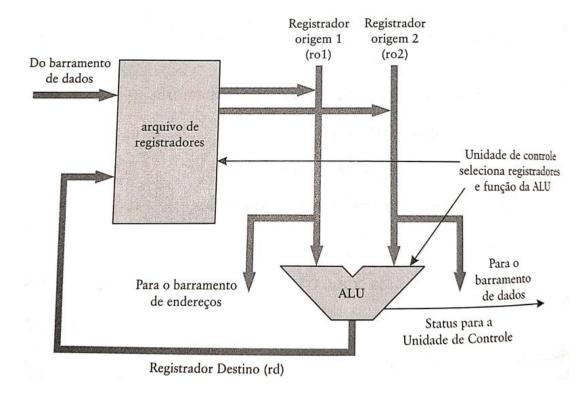
OBS: Lembre-se: os registradores são circuitos sequenciais formados a partir de flip-flops!

OBS2: O arquivo de registradores é, geralmente, associado somente aos registradores da parte de processamento. Entretanto, algumas literaturas e fabricantes atribuem o título "arquivo de registradores" a **todo** o conjunto de registradores do sistema (incluindo os de controle). Estamos considerando, aqui, o segundo caso.



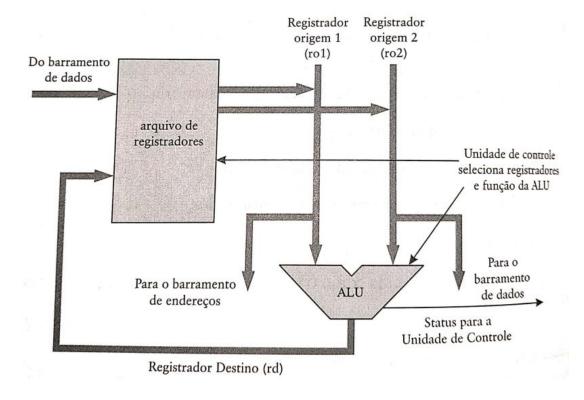


- Na UCP, os dados (vindos através do barramento de dados) são armazenados, temporariamente, em registradores, os quais enviam a informação para a ULA. O resultado do processamento é enviado para um outro registrador, onde fica armazenado;
- A partir daí, o dado pode ser utilizado em um novo cálculo ou pode ser salvo na memória principal. A ULA pode ter também operado números cujo resultado seja um endereço, o qual deve ser enviado pelo barramento de endereços.





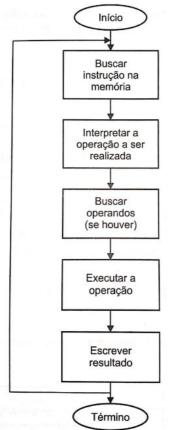
- A unidade de controle envia para a ULA qual operação ela deve realizar (uma soma, subtração, operação AND, operação NOR, entre outras possíveis);
- Ela também define quais os registradores que devem ser acessados para determinada operação, dita o sincronismo do sistema e envia sinais de controle para os outros componentes, de forma a fazer com que cada um funcione na hora certa e do jeito certo.





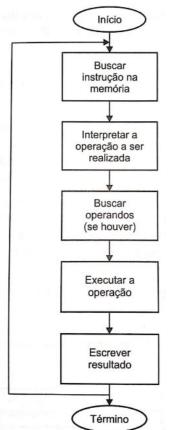
- Como um microprocessador executa uma instrução? Quais são os "passos" que ele segue ao receber um comando e gerar uma saída?
- A sequência de ações que um microcontrolador realiza para executar uma instrução é o chamado ciclo de instrução, conhecido também como ciclo de busca-decodificação-execução (fetch-decode-execute cycle) ou, simplesmente, ciclo de busca-execução (fetch-execute cycle).





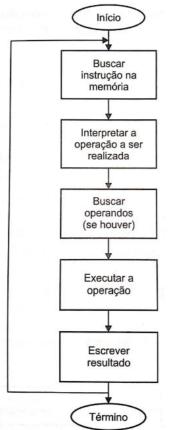
- A figura ao lado ilustra, basicamente, como ocorre o ciclo de instrução:
- Quando solicitamos que o processador execute um programa, ele vai buscar na memória qual a primeira instrução que deve ser executada;
- Em seguida, ele irá decodificar a instrução e gerar os sinais de controle apropriados para que a instrução seja executada. Esses sinais de controle podem ser gerados de forma direta, utilizando um circuito combinacional, ou por meio de uma interpretação das instruções, a qual ocorre com o auxílio de um microcódigo;
- No próximo momento, ele vai buscar (caso existam) os operandos da instrução, ou seja, os dados que serão utilizados na realização das operações solicitadas.





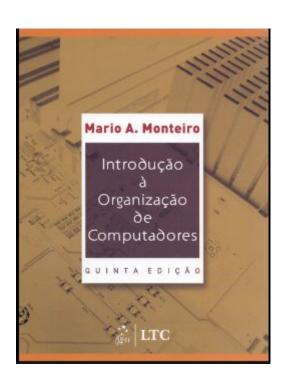
- Após saber a operação que ele deve realizar e quem são os dados que devem ser operados, o processador realiza a operação em si;
- Por fim, após a execução, o processador retorno o resultado final da operação;
- Após o resultado final ser gerado, o processador começa todo o processo novamente.





- No fluxograma, a indicação de "início" representa, por exemplo, o momento em que ligamos o computador, enquanto o "término" representa o momento em que desligamos;
- O processador, portanto, segue esse passo a passo várias vezes durante o período em que estiver processando informações, parando somente ao ser desligado, reiniciado ou receber um explicitamente uma instrução de parada;
- A ordem de execução de várias instruções é definida pela organização do programa que foi repassado ao processador.

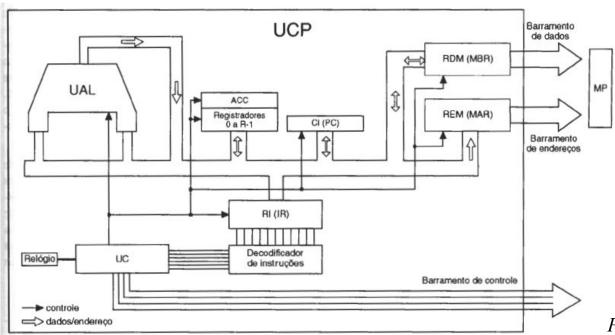




- Não há, entre os livros da área de arquitetura de computadores/microprocessadores, um consenso entre o que seria uma arquitetura básica, genérica e ideal – cada livro costuma criar uma arquitetura didática e discutir vários conceitos a partir dela;
- Em nosso caso, iremos utilizar, nesse momento, o livro "Introdução à Organização de Computadores" (5ª edição), do Prof. Monteiro, o qual mostra um sistema bem genérico, simples e poderemos utilizar como base;
- Em aulas futuras, iremos nos aprofundar em uma dessas arquiteturas didáticas, a qual chamaremos de SAP (Simple-As-Possible Computer).



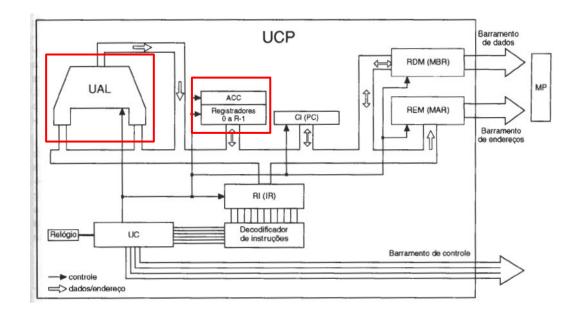
• Temos, na figura abaixo, os componentes principais de um microprocessador, dentre os quais podemos destacar a ULA/UAL e a UC. Além disso, é possível visualizar vários registradores, o decodificador de instruções e o relógio do sistema.



Prof. Alan Sovano

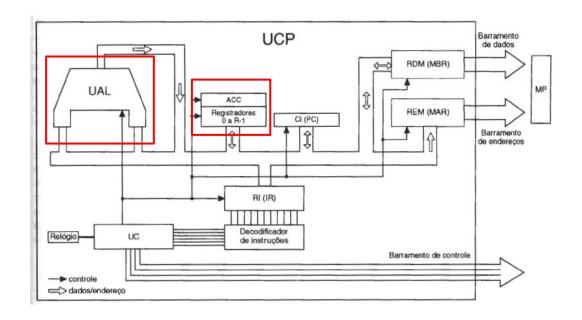


- Os componentes marcados em vermelho destacam os blocos de processamento (a ULA/UAL e os registradores utilizado para armazenamento de dados);
- Nesse sistema, é mostrado um registrador especial chamado de ACC (acumulador).
 Um registrador acumulador guarda resultados intermediários que serão utilizados novamente no programa (seu uso ficará mais claro quando falarmos do nível ISA);
- Nesse momento, o que importa é saber que o registrado ACC e os registradores de 0 a R-1 são todos registradores de dados.





- Vale ressaltar que um processador não precisa, necessariamente, ter uma única ULA/UAL, podendo ter várias para realizar múltiplas operações ao mesmo tempo;
- O ATMega328p, por exemplo, possui uma única ULA/UAL em sua UCP, enquanto um Intel Core i7 de 13^a geração possui múltiplas ULAs/UALs.





- Na figura ao lado, temos as entradas e saídas de uma ULA/UAL;
- Os **sinais de controle** determinam qual operação será realizada pela ULA/UAL, enquanto as entradas de registradores são as entradas de dados em si:
- O resultado da operação é direcionado saída para registradores. Dependendo do resultado e operação, valores diferentes transmitidos à saída para flags e chegam ao registrador de controle (OBS: esse registrador não aparece na figura do slide anterior e nem na figura ao lado, mas aparece na figura do próximo slide).

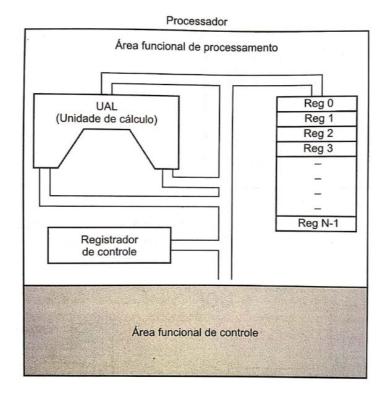


Figura 6.10 Interligação da UAL ao restante da UCP.



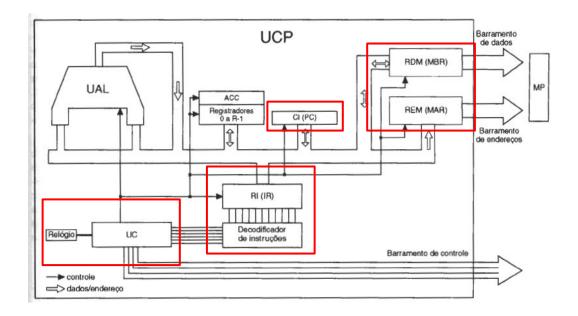
- Uma *flag* é uma "sinalização" para o sistema de que algum processo específico ocorreu;
- A ULA/UAL pode usar um *flag* para indicar que ocorreu, por exemplo um *carry* ou um *overflow* em uma operação aritmética específica;
- A ULA/UAL envia uma *flag* para o sistema como um conjunto de bits, os quais são salvos em um registrador específico para esse fim;
- As *flags* indicam ações específicas que a unidade de controle deve tomar para continuar com o processamento da informação.

OBS: Não existem somente *flags* geradas pela ULA/ALU. Elas também podem ser setadas diretamente através de um programa ou por dispositivos de E/S (**exemplo:** *flag* para indicar uma interrupção do sistema).



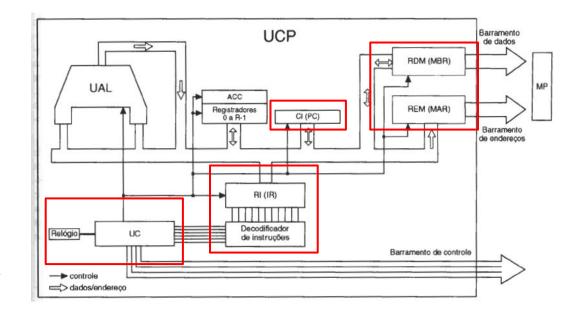


- Agora, em nossa figura que ilustra a microarquitetura de um processador genérico, temos destacados os blocos que participam das tarefas de controle do sistema;
- Entre as tarefas de controle, estão a busca (na memória principal) da instrução que deve ser executada e a decodificação dessa instrução (com o auxílio de um microcódigo ou de um circuito combinacional). Essas etapas constituem o ciclo de busca da instrução (fetch cycle), junto com o ciclo de decodificação da instrução (decode cycle);
- A instrução, ao ser decodificada, se transforma em vários sinais de controle para o resto do sistema, ordenando o que cada componente deve fazer a cada instante de tempo para que a instrução seja realizada com sucesso. Esse é o ciclo de execução da instrução (execute cycle);
- A unidade de controle, portanto, é a responsável principal por ordenar o ciclo de busca-decodificação-execução.



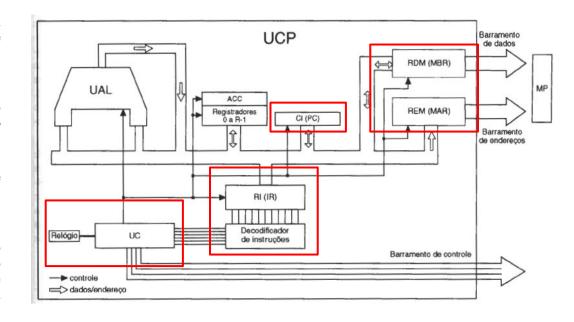


- Na figura ao lado, temos em destaque:
 - O relógio (*clock*) do sistema;
 - A UC (unidade de controle) propriamente dita;
 - O decodificador de instruções;
 - O Registrador de instruções (RI) ou *Instruction* Register (IR);
 - O Contador de Instruções (CI), Program Counter (PC) ou, ainda, Instruction Pointer (IP);
 - O Registrador de Dados de Memória (RDM) ou *Memory Buffer Register (MBR)*;
 - O Registrador de Endereços de Memória (REM) ou *Memory Address Register (MAR)*.



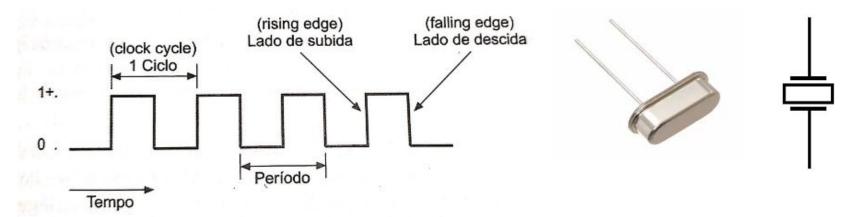


- A UC gera vários sinais de controle para o resto do sistema de forma temporizada, onde o ciclo de instrução é executado em uma ou mais sub etapas, as quais são chamadas de microeventos ou microoperações;
- A microoperação é a menor operação possível que um processador pode realizar (por exemplo, passar a informação de um registrador para outro ou guardar a informação do barramento de dados em um registrador);
- As microoperações levam, geralmente, um ciclo do sinal de clock. Várias microoperações podem ser realizadas conjuntamente;
- As microoperações podem ser geradas a partir de um processo de decodificação com execução direta da instrução (usando um circuito combinacional); ou a partir de um processo de decodificação seguido de interpretação (com um microcódigo);
- No microcódigo são programadas as microinstruções, que especificam uma ou mais microoperações.



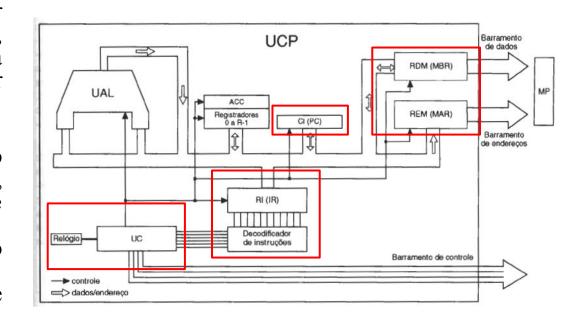


- Em um processador, o que dita o sincronismo das ações é o sinal de *clock*;
- O *clock* é gerado, usualmente, por um **circuito oscilador** onde um de seus elementos é um **cristal de quartzo**, principal componente responsável pelas altas frequências (a partir de MHz) e estabilidade do sinal de *clock*;
- Relembrando: um sinal de *clock* possui uma borda de subida e uma de descida. A distância entre duas bordas de subida ou dias bordas de descida consecutivas nos fornece o **período** do sinal de *clock*.



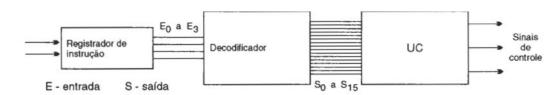


- Para a unidade de controle gerar os sinais de controle apropriados, além da temporização, ela precisa saber qual instrução deve ser realizada;
- Cada instrução tem um código específico, o código de operação, que é guardado no registrador de instruções (RI) e, após esse código ser decodificado pelo decodificador, um modo de operação específico da unidade de controle é acionada.





- A figura ao lado ilustra a relação entre o RI, o decodificador e a UC;
- A tabela verdade mostra que cada código de operação possível no RI ativa somente uma entrada da UC (referente a uma instrução, por exemplo);
- A unidade de controle pode ter outras entradas além das que vem diretamente do decodificador (que podem estar relacionadas aos *flags* do sistema, por exemplo);
- As saídas da UC são os sinais de controle propriamente ditos (que vão definir como o sistema irá operar naquele momento).



(a) Diagrama em bloco da decodificação em uma UCP

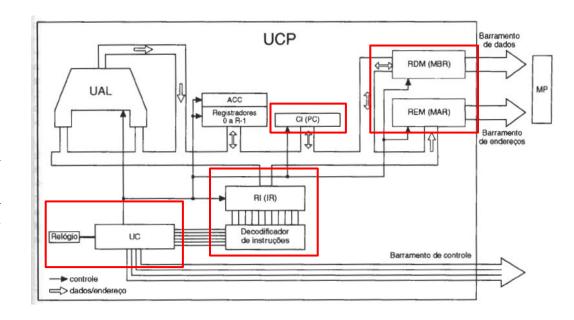
E ₀	E ₁	E_2	E_3	s_0	s_1	s_2	S_3	S ₄	s_5	s_6	S ₇	S ₈	S_9	S ₁₀	S ₁₁	S ₁₂	S ₁₃	S ₁₄	S ₁₅
0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	1	1	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	1	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	1	1	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0
	1	0	0	0	0	0	0	1	0	0	0		0	0	0	0 0 0	0 0 0	0 0 0	0 0 0
0	1	0	1	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0
0 0 0 0 1	1	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0
0	1	1	1	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0
1	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0		0	0	0
1	0	0	1	0		0		0	0 0 0	0	0	0	1	0 0 1	0	0	0	0 0 0	0
1	0	1	0	0	0	0	0	0	0	0	0	0	0	1	0	0		0	0
1	0	1	0	0	0 0	0	0	0	0	0	0 0	0	0	0	1	0	0		0
1	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0
1	1	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0
1	1	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0
1	1	1	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1

(b) Linhas de Saída



- Como o processador sabe qual instrução acessar? É aí que entra o Contador de Instruções (CI) ou Program Counter (PC);
- Quando o sistema é iniciado (ou reiniciado), o registrador CI é inicializado com algum valor, o qual indicará a primeira coisa a ser feita (por exemplo, o sistema pode começar lendo sempre o primeiro endereço da memória de programa);
- Após a instrução ser buscada e salva pelo processador (fim da fase de busca de instrução, ou seja, quando o processador tem a informação do que deve fazer), o registrador CI pode ter o seu valor incrementado, devendo esse processo ocorrer antes da busca da próxima instrução. Após esse incremento, a próxima etapa de busca de instrução irá para o próximo endereço da memória de programa.

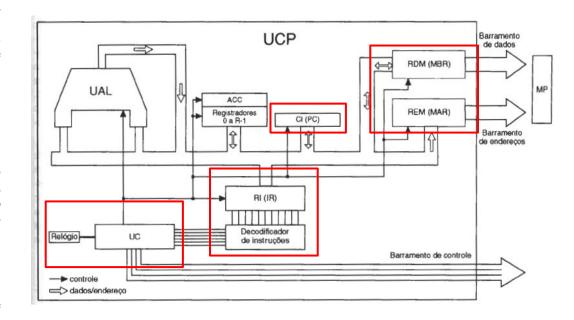
OBS: Algumas instruções alteram o valor do registrador CI para que haja um **salto** no endereço de memória que vai ser lido (veremos isso ao falarmos do nível ISA).





- Por fim, temos mais dois registradores nessa arquitetura genérica: um deles é o Registrador de Dados de Memória (RDM) ou Memory Buffer Register (MBR). O RDM salva os dados que irão entrar ou sair do processador e, portanto, ele possui comunicação direta com o barramento de dados;
- O outro registrador é o Registrador de Endereços de Memória (REM) ou Memory Address Register (MAR). Ele envia o endereço, especificado pelas instruções do programa, que deve ser utilizado para acessar determinada informação. Esse endereço pode ser relacionado a um dado específico (memória de dados) ou a localização de uma próxima instrução (memória de programa). Nesse último caso, o endereço para acessar a memória de programa vem do registrador CI.

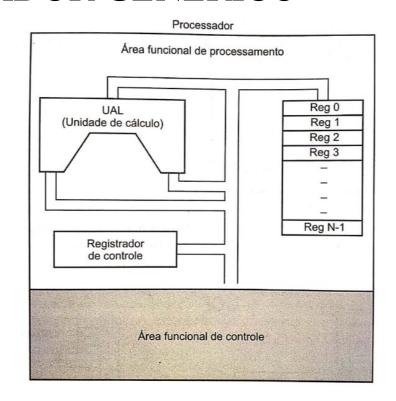
OBS: Os registradores CI e REM devem ter o mesmo tamanho, o qual deve ser, via de regra, o mesmo do barramento de endereços. A partir do tamanho do registrador REM, pode-se saber o número máximo de endereços que podem ser acessados pelo processador em questão. De forma similar, via de regra, o registrador RDM deve ter o mesmo tamanho do barramento de dados.





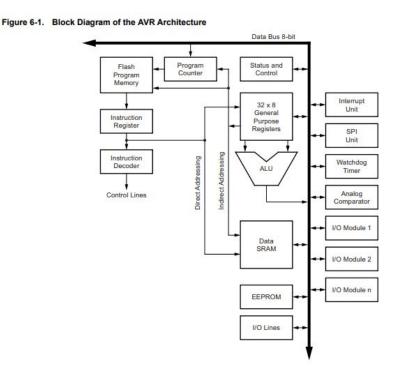
OBS: O registrador de controle, apesar de descrito ao falarmos da parte de **processamento dos dados**, na prática, exerce tanto funções de **processamento** quanto de **controle**, de acordo com as *flags* definidas para esse registrador.

OBS2: Esse registrador também é chamado em algumas folhas de dados de **PSW** (*Program Status Word*).





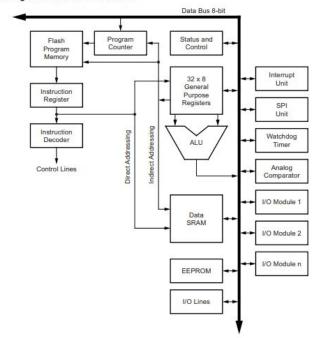
- Ao lado, vemos a microarquitetura de um microprocessador AVR (o qual está presente no ATMega328p, microcontrolador da placa Arduino UNO);
- Conseguimos identificar muitos dos blocos genéricos que estudamos: a ULA (ou ALU); os registradores da área de processamento (General Purpose Registers); o registrador de controle (status and control); o contador de programa (program counter); o registrador de instruções (instruction register); o decodificador de instruções (instruction decoder).





- Vale ressaltar que, no diagrama, o decodificador de instruções é, na verdade, o decodificador de instruções mais a unidade de controle (UC) que vimos em nossa arquitetura genérica. Podemos ver isso pois sua entrada vem do registrador de instruções e sua saída vai para o barramento de controle;
- Perceba também que alguns dos elementos que estudamos não estão ilustrados na figura, mas eles existem! Um exemplo muito claro disso é sinal de *clock*, necessário para todo e qualquer processador, mas omitido no diagrama;
- Isso nos mostra algumas coisas importantes: não há um consenso na melhor forma de mostrar o nível de microarquitetura e, além disso, podem haver nomenclaturas diferentes utilizadas por cada fabricante;
- Por esses motivos, mesmo tendo os conceitos básicos em mente, é sempre interessante estudar a folha de dados do componente que você deseja utilizar!

Figure 6-1. Block Diagram of the AVR Architecture





- Existem tipos específicos de dados com os quais um processador consegue trabalhar.
 Esse tópico busca mostrar como esses dados são representados e manipulados em um sistema microprocessado;
- Os tipos de dados a serem apresentados são os principais, com muitos processadores possuindo instruções específicas no nível ISA para manipulá-los;
- Vamos começar dividindo os tipos de dados em duas classes: numéricos e não-numéricos.



- Os dados do tipo **numérico** podem ser representados em uma estrutura chamada de **ponto-fixo** ou em outra chamada de **ponto flutuante**;
- Na estrutura com ponto fixo, o processador entende que a vírgula está **fixada** antes/depois de algum bit específico do registrador. A aritmética com números em ponto fixo ocorre utilizando, geralmente, a **notação em complemento de 2**. Também podem ser utilizadas a **notação sinal-módulo** e a **notação em complemento de 1**;
- Quando falamos em **ponto fixo**, muitas vezes estamos nos referindo aos **números inteiros** a vírgula está fixada à direita do bit menos significativo (LSB).



Uma característica importante da representação em complemento de 2 é a seguinte: se tivermos um conjunto de N bits, o número positivo de maior módulo que podemos representar, D, e o número negativo de maior módulo que podemos representar, D, serão iguais a:

$$D_{+} = (2^{N-1}-1)$$

$$D = -(2^{N-1})$$

• Nas notações sinal-módulo e complemento de 1, temos que os mesmos números D_{\perp} e D são dados por:

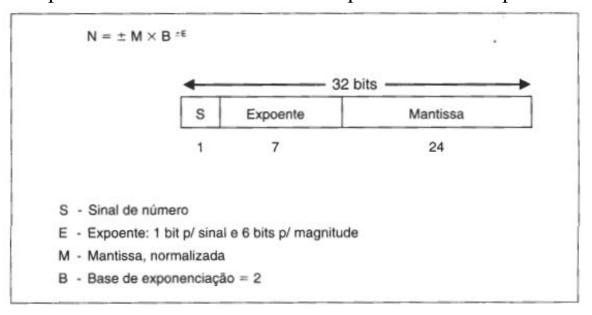
$$D_{+} = (2^{N-1}-1)$$

$$D = -(2^{N-1}-1)$$

- Ou seja, na notação em complemento de 2, somos capazes de representar um valor negativo a mais, sendo uma notação mais eficiente nesse sentido;
- Além disso, é mais fácil construir um circuito que realiza operações aritméticas com números inteiros ao utilizar a notação em complemento de 2 (em comparação com a aritmética baseada na notação em complemento de 1 ou notação sinal-módulo).



• Na estrutura com **ponto flutuante** (onde a vírgula não fica fixada antes/depois de um bit específico), os números são representados em um formato relacionado à **notação científica**, para expressarmos **números reais**. O quadro abaixo representa esse processo.





- Os expoentes de um número em ponto flutuante são representados comumente na notação **excesso de N**, a qual elimina a necessidade de um bit de sinal para o expoente;
- Em notação excesso de N, encontra-se o valor C na expressão:

$$C = (2^{n}/2 - 1) + E$$

- Onde "C" é o número que será armazenado no campo de expoente, "E" é o valor real do expoente e "n" é o número de bits utilizados para armazenar o expoente. O valor (2ⁿ/2 1) é o chamado **excesso**;
- A notação em excesso de N faz com que não haja a necessidade de um bit de sinal para o expoente. Além disso, ela facilita a comparação entre os expoentes (um número binário maior representa o expoente maior nesse caso, algo facilmente verificável por um circuito lógico apropriado);

OBS: A mantissa costuma ser representada na notação **sinal-módulo** em operações envolvendo ponto flutuante em um processador.



Exemplo: Uma unidade de ponto flutuante utiliza 8 bits para armazenar expoentes. Para escrever o expoente das potências 2¹⁰ e 2⁻¹⁵ teríamos que realizar as seguintes operações:

$$C = (2^8/2 - 1) + 10 = 127 + 10 = 137$$

$$C = (2^8/2 - 1) - 15 = 127 - 15 = 112$$

Portanto, o excesso de 127 do expoente 10 é 137, enquanto o do expoente -15 é 112.



• O padrão mais utilizado para ponto flutuante é o IEEE-754, o qual tem algumas de suas características descritas na tabela abaixo:

Tabela 7.6 Características dos Formatos Básicos de Números em Ponto Flutuante, Representados no Padrão IEEE-754

	Precisão simples	Precisão dupla			
Total de bits do número	32 bits	64 bit			
Quant. bits para sinal	1 bit	1 bit			
Bits para expoente	8	11			
Bits para significando	23	52			
Cálculo do expoente	Excesso de 127	Excesso de 1023			
Faixa de representação em decimal	Aprox. 10 ⁻³⁸ até 10 ⁺³⁸	Aprox. 10 ⁻³⁰⁸ até 10 ⁺³⁰⁸			



- No padrão IEEE-754, para escrever a mantissa (na tabela chamada de *significando*), sempre consideramos que ela começa com a parte inteira igual a 1. No campo da mantissa, portanto, sempre colocamos a parte **não-inteira**;
- Escrevemos a parte do expoente, quando o número é escrito em precisão simples, sempre utilizando a notação em excesso de 127;
- No padrão IEEE-754, algumas notações são reservadas para escrever +∞, -∞ e NaN (*Not a Number* ou "não é um número").
- **OBS:** Um exemplo de operação que retorna NaN é 0/0 (operação sem valor definido).



- Não iremos entrar em detalhes sobre a representação em ponto flutuante e a aritmética em ponto flutuante, mas devemos entender que essa é a representação utilizada na maioria dos processadores que manipulam números que possuem uma parte que não é inteira. Detalhes sobre esse tipo de notação podem ser encontrados na norma IEEE-754 ou em livros que descrevem como trabalhar com ponto flutuante;
- É possível implementar, via software, operações com ponto flutuante em sistemas que possuem somente ULA's que trabalham com números inteiros. Apesar de uma solução viável, não é uma forma eficiente de realizar cálculos com números fracionários;
- Atualmente, os processadores possuem **unidades de ponto flutuante** (UPF ou FPU) implementadas em hardware para trabalhar, especificamente, com operações de números na notação em ponto flutuante.



- Os primeiros processadores não tinham uma FPU embutida na CPU. A FPU era um componente extra, mas que funcionava em conjunto com a CPU, sendo também por isso chamada de **coprocessador**;
- Um **coprocessador** auxilia a função do processador principal. Outro exemplo clássico de coprocessador é a placa de vídeo ou GPU (*Graphical Processing Unit* ou unidade de processamento gráfico);
- Atualmente, muitas CPU's já vem com uma FPU embutida. Em nossos estudos de um microprocessador genérico, não consideramos a FPU como elemento essencial isso porque um processador é capaz de funcionar sem ela;
- O microcontrolador ATMega328p, por exemplo, não possui uma FPU em sua CPU.



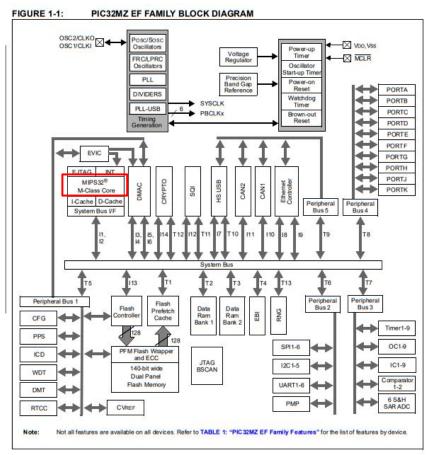
- Computadores podem ter seus desempenhos medidos em FLOPS ou FLOP/s
 (floating-point operations per second ou operações em ponto flutuante por segundo),
 indicando a velocidade com que um computador realiza cálculos com números em ponto
 flutuante;
- **OBS:** Outra forma de avaliar a velocidade dos computadores é utilizando a medida de IPS (*Instructions per Second* ou instruções por segundo). Geralmente é utilizado o seu múltiplo, MIPS (ou Mega IPS).



- Para finalizar o nosso estudo sobre FPU's, repare na figura do próximo slide ela mostra a microarquitetura de um microcontrolador PIC32MZ EF, o qual possui um microprocessador MIPS32 M-class
- **OBS:** Aqui, MIPS significa *Microprocessor without Interlocked Pipelined Stages* (Microprocessador sem estágios de *pipeline* intertravados), uma arquitetura de conjunto de instruções (ISA) desenvolvida pela MIPS Technologies (não confunda com a definição anterior de MIPS, que é uma medida de desempenho!). O MIPS32 M-Class é um microprocessador que funciona baseado na arquitetura MIPS.



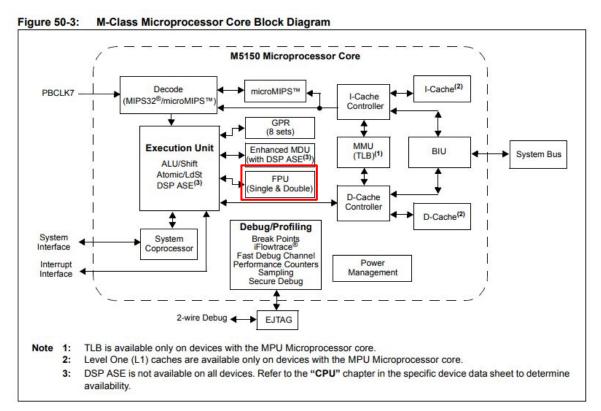
- Na figura ao lado, temos a microarquitetura de um PIC32MZ EF, o qual possui um microprocessador MIPS32 M-Class;
- O próximo slide mostra a microarquitetura do MIPS32 M-Class.



Prof. Alan Sovano



- Podemos perceber que, entre várias coisas, o MIPS32 M-Class possui a FPU, como estávamos discutindo!
- Perceba um microprocessador pode ter muitos elementos em sua microarquitetura, ficando cada vez mais complexo;
- Para utilizar bem um microprocessador e/ou um microcontrolador, deve-se realizar sempre um estudo da folha de dados do componente!





- Além de números em ponto fixo e em ponto flutuante, outra forma de representar dados numéricos é com uma codificação em decimal;
- Pense o seguinte: alguns números decimais, como 3,2₁₀, não podem ser exatamente convertidos para binário se você tentar realizar essa conversão, chegará no número (11,001100110011...)₂, uma dízima periódica (binária). Como um computador tem um número limitado de bits, ele não consegue representar **exatamente** o valor 3,2₁₀ dessa forma ele irá truncar ou arredondar o valor;
- Em algumas aplicações isso não é viável. Truncamentos e arredondamentos introduzem **erros** nos nossos cálculos. Se truncarmos o número (11,001100110011...)₂ e escrevermos ele como 11,0011₂, ao realizar a conversão de volta para decimal, obtemos o número 3,1875₁₀, ficando evidente que o processo de conversão resultou em um erro, em uma perda de informação;
- Imagine uma calculadora sendo utilizada em um estabelecimento comercial que apresentasse esse tipo de erro: ou o estabelecimento ou o cliente acabariam perdendo dinheiro!



- Por esse motivo, em alguns sistemas (principalmente relacionados a cálculos envolvendo valores monetários), há um dado numérico do tipo **decimal**;
- Na prática, há um processo de codificação cada dígito decimal é representado por um número binário (o que é diferente de representar o valor diretamente em binário);
- Um exemplo desse processo é a codificação BCD (*Binary Coded Decimal*), a qual representa cada dígito decimal através de uma combinação de 4 bits;
- Portanto, para representar um dado numérico do tipo decimal com dois dígitos seria necessário, por exemplo, um registrador com 8 bits.



- A figura ao lado mostra como a codificação BCD ocorre;
- Realizar operações aritméticas utilizando dados em BCD é algo mais complexo do que realizar operações com números em ponto-fixo (inteiros);
- A aritmética utilizando dados decimais codificados em BCD pode exigir instruções e/ou hardware específico.

OBS: é possível implementar, via software, operações com dados do tipo decimal em sistemas que trabalham unicamente com dados em ponto-fixo (inteiros).

Decimal	Binário — BCD		
0	0000		
1	0001		
2	0010		
3	0011		
4	0100		
5	0101		
6	0110		
7	0111		
8	1000		
9	1001		



- Além dos dados numéricos, tempos os dados não-numéricos. Temos dois tipos de dados não-numéricos: os **lógicos** e os **caracteres**;
- Os dados lógicos são representados de forma muito simples um bit que tem seu valor igual a 1 representa uma condição **verdadeira**, enquanto um bit com um valor igual a 0 representa uma condição **falsa**;
- **Exemplo:** se a ULA de um processador faz a operação lógica AND entre o conteúdo de dois registradores de 4 bits, onde o primeiro registrador possui os bits é 1100 e o segundo possui 0101, a saída da ULA será:

	0	1	0	0	_
AND	0	1	0	1	
	1	1	0	0	



- Temos, por fim, os dados do tipo caractere. Assim como no dados numéricos decimais, os dados do tipo caractere precisam de uma codificação;
- Podemos citar duas codificações comuns: **ASCII** (*American Standard Code for Information Interchange*) e o **UNICODE**;
- O ASCII representa os caracteres em uma codificação que utiliza 7 bits. Há também o ASCII estendido, o qual utiliza 8 bits (incluindo mais caracteres);
- A codificação ASCII possui, majoritariamente, caracteres associados ao alfabeto latino. Para outros tipos de caracteres (que incluem o alfabeto grego, por exemplo), é utilizada a codificação UNICODE, a qual pode utilizar 8, 16 ou até 32 bits;
- Os processadores costumam possuir instruções específicas para manipular cadeias de caracteres (*strings*).

OBS: Nas *strings*, cada caractere é geralmente representado por 1 byte (8 bits). Para indicar o término da *string*, há um caractere nulo em seu fim (onde o valor de todos os bits do byte é igual a zero), geralmente representado por "\0".



most significant nibble

_5 _6 _7 _8 _9 _A _B _C _E _F

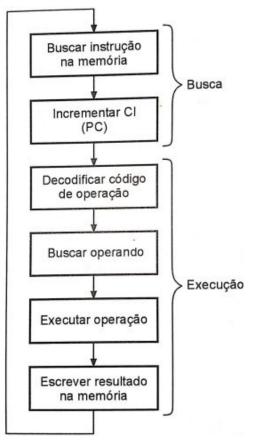
0_	1_	2_	3_	4_	5_	6_	7_
NUL	DLE	SP	0	@	Р		р
SOH	DC1	İ	1	Α	Q	а	q
STX	DC2		2	В	R	b	r
ETX	DC3	#	3	С	S	С	s
EOT	DC4	\$	4	D	Т	d	t
ENQ	NAK	%	5	E	U	е	u
ACK	SYN	&	6	F	V	f	٧
BEL	ETB	1	7	G	W	g	w
BS	CAN	(8	Н	Х	h	х
HT	EM)	9	I	Υ	i	у
LF	SUB	*	÷	J	Z	j	z
VT	ESC	+	÷	K	[K	}
FF	FS	,	<	L	1	I.	1
CR	GS	-	=	М]	m	}
so	RS		>	N	۸	n	~
SI	US	1	?	0	_	0	DEL

- A tabela ao lado mostra como a codificação em ASCII ocorre. Cada caractere está codificado com dois dígitos hexadecimais, representando 8 bits;
- Nessa codificação do ASCII, o bit mais significativo é sempre 0 (os caracteres são representados, de fato, por 7 bits, com 1 bit extra para completar o tamanho total de 1 byte).



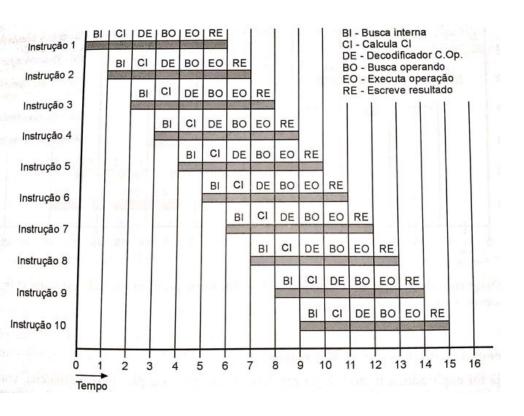
- Ao estudar o ciclo de busca-decodificação-execução, vimos que o processador, a princípio, funciona de forma sequencial;
- Acontece que existem etapas desse ciclo que podem ser feitas ao mesmo tempo para instruções diferentes. Por exemplo, enquanto uma instrução está na fase de decodificação, a próxima já poderia entrar na fase de busca de instrução;
- Esse procedimento acontece nos processadores atuais, os quais funcionam como uma **linha de montagem** (um *pipeline*), sofrendo um processo de **canalização** ou *pipelining* de instruções.





 Considere um ciclo de instrução dado pelo fluxograma ao lado, o qual será utilizado como base para discutir o pipelining.

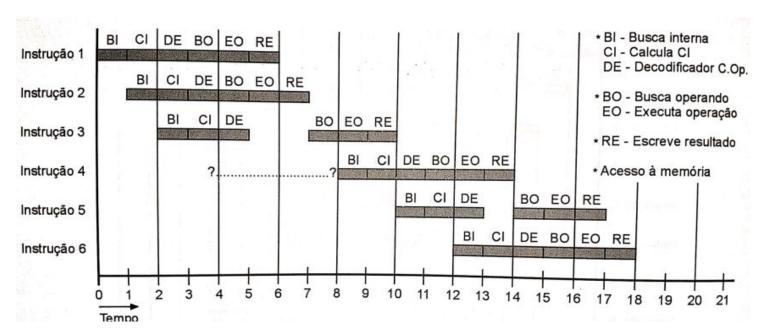




- Se cada etapa do ciclo de instrução for executada por uma parte diferente do sistema, várias instruções podem ser executadas ao mesmo tempo;
- A primeira instrução levará, em nosso exemplo, 6 ciclos de relógio para ser executada (considerando que cada etapa leva um ciclo de *clock*);
- Após a execução da primeira instrução, com o *pipelining*, a cada próximo ciclo de *clock*, uma nova instrução será finalizada, aumentando a eficiência do microprocessador;
- Esse *pipeline*, idealmente, realiza todas as 6 etapas do ciclo de instrução ao mesmo tempo, com cada etapa sendo referente a uma instrução diferente!

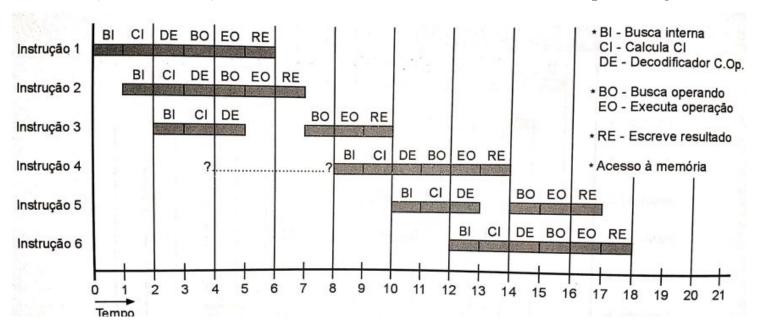


• Na prática, não temos como realizar todas as etapas ao mesmo tempo – algumas necessitam das mesmas partes do sistema.



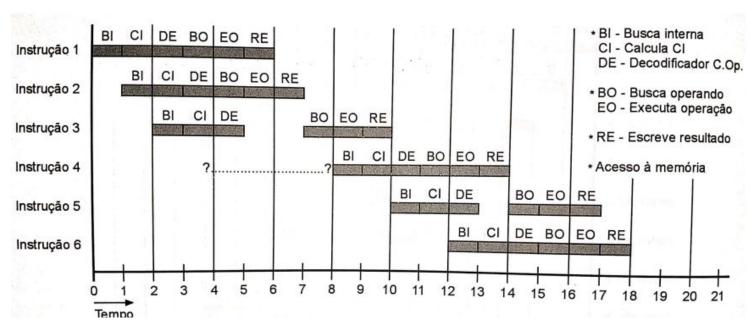


• Vamos considerar, agora, que as etapas BI, BO e RE precisam acessar o barramento de dados para se comunicar com a memória principal (leitura/escrita de dados na memória principal). Nesse caso (mais realista), haverá um conflito de acesso à memória por estágios diferentes.





• Dessa forma, a eficiência do *pipeline* é limitada por diversos fatores práticos.



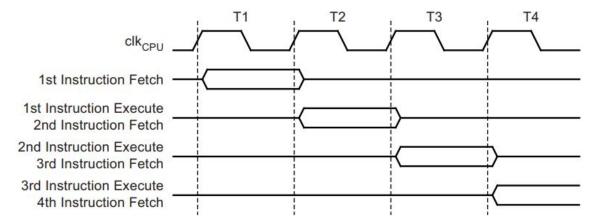


- Em nosso exemplo, consideramos que a busca de instruções e de dados ocorre pelo mesmo barramento (processador operando em um computador com arquitetura de Von-Neumann);
- Se houvesse uma separação da memória de programa (instruções) da de dados (arquitetura Harvard), haveria a possibilidade de obter um *pipelining* mais eficiente;
- Logo, podemos concluir que a arquitetura Harvard é uma solução melhor para a implementação de um *pipeline* em comparação com a de Von-Neumann;
- **OBS:** Na prática, outros fatores também limitam o *pipelining*, como o tempo de duração de cada etapa (que não é necessariamente igual) ou a utilização de instruções de **salto** ou **desvio** (que altera a ordem de execução de instruções). Há também a possibilidade da próxima instrução precisar de dados da instrução anterior, havendo um atraso na execução dessa próxima instrução. Todos esses problemas devem ser considerados ao implementar um *pipeline*.



• No *datasheet* do ATMega328p, é descrito que seu microprocessador tem um *pipeline* simples de dois estágios: enquanto há a busca de uma instrução, há a execução de outra. Lembre-se: o ATMega328p é um microcontrolador que possui arquitetura Harvard!

Figure 6-4. The Parallel Instruction Fetches and Instruction Executions





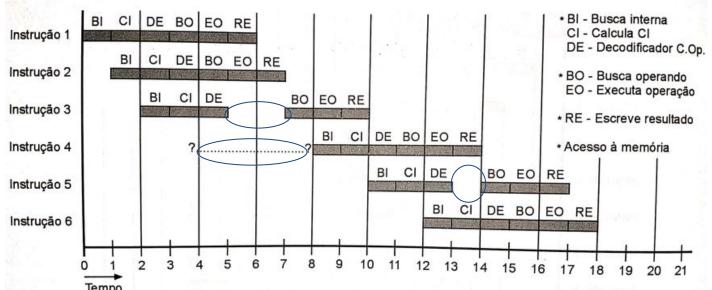
- Quando falamos da implantação de um *pipelining* no processador, estamos tentando fazer com que o processador seja capaz de fazer mais coisas ao mesmo tempo. É uma tentativa de processar mais informação ao mesmo tempo, ou seja, em **paralelo**;
- Os problemas que podem ocorrer em um *pipeline* também são chamados de *hazards* (perigos). Existem três tipos de *hazards* possíveis: os *hazards* estruturais, *hazards* de dados e *hazards* de controle.



- Hazards estruturais ocorrem quando estágios diferentes do pipeline precisam de um mesmo recurso (exemplo: duas instruções que precisam acessar a memória ao mesmo tempo);
- Hazards de dados ocorrem quando há uma dependência de dados entre instruções.
 (exemplo: quando uma instrução de soma gera uma valor qualquer, e a próxima instrução depende desse valor nesse caso, a próxima instrução só poderá ser executada quando a primeira for finalizada);
- *Hazards* de controle ocorrem quando instruções entram no *pipeline* sem necessidade, e acabam sendo descartadas (exemplo: quando um instrução de desvio aparece no programa, mudando a sequência de instruções que devem ser executadas).



• Existem várias técnicas para se lidar com *hazards* em pipelines. Uma delas é a inserção de bolhas (*bubbles*), que são momentos ociosos dentro do *pipeline*. Retomando o nosso exemplo anterior do *pipeline* com conflitos de acesso à memória (*hazard* estrutural), podemos ver as bolhas (em azul) inseridas para evitar problemas durante o processamento.



Prof. Alan Sovano



- Os gargalos do *pipelining* levaram ao desenvolvimento de outras técnicas complementares de **paralelização**;
- Uma delas é a utilização de múltiplos núcleos (*cores*) em um único circuito integrado. Cada núcleo funciona como um processador independente, com um único circuito integrado sendo capaz de realizar várias *threads* ao mesmo tempo, associados a um mesmo **processo**.



- O conceito de processo está associado ao estudo de sistemas operacionais. Um processo pode ser definido como a instância de um programa em execução;
- Um programa, ao ser executado, tem, de forma geral, recursos alocados (como memória, contador de programa, registradores para processamento, entre outros), um estado (aguardando execução, em execução de fato ou bloqueado) e um identificador (PID ou identificador de processo). Esse conjunto de fatores necessários para caracterizar um programa que foi colocado em execução é o que define um processo;
- Quando você clica no ícone para abrir um editor de texto, por exemplo, você está iniciando um processo você começou a execução de um programa. Se você clicar de novo no ícone do editor e "abrir o programa de novo", você está iniciando um novo processo de um mesmo programa.



- Esse mesmo editor de texto pode ter seu processo subdividido em etapas que podem ocorrer ao mesmo tempo: o salvamento dos arquivos automaticamente, a correção da ortografía e recebimento de caracteres de entrada;
- Cada uma desses *caminhos de execução* é independente um do outro, podendo todos serem processados ao mesmo tempo, mas estão todos relacionados ao mesmo **processo** (compartilham recursos alocados para o processo). Essas subdivisões de etapas são as *threads*;
- Cada *thread* pode ser executada por um núcleo de processamento, aumentando a capacidade de processamento em paralelo do sistema;
- Todo processo deve ter ao menos uma thread, mas pode ter várias.

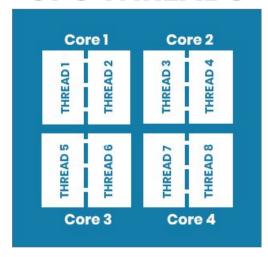


- Sistemas com múltiplos núcleos suportam *multithreading*, onde cada núcleo é capaz de trabalhar com uma *thread*, aumentando o paralelismo da execução de um programa e, consequentemente, fazendo com que o sistema faça mais coisas ao mesmo tempo;
- Existem processadores onde um núcleo de processamento consegue executar mais de uma *thread*, criando a ideia de um "núcleo virtual" de processamento;
- Quando um processador tem 8 *cores* e 16 *threads*, por exemplo, significa que o sistema tem 8 núcleos físicos de processamento, com cada um suportando, a princípio, 2 *threads* por vez;
- Essa é a base do funcionamento de técnicas como o *hyperthreading* da Intel.



• Quando um núcleo físico executa duas *threads* de uma vez, na prática, essas *threads* não são executadas perfeitamente em paralelo – uma acaba, em algum momento, precisando esperar a outra ser executada. Quando temos vários núcleos físicos, a execução (comparando um núcleo com outro) pode ser perfeitamente paralela.

CPU THREADS





OBRIGADO PELA ATENÇÃO!

Dúvidas ou sugestões?

sovano@ufpa.br